第26卷 第6期 工 程 数 学 学 报 Vol. 26 No. 6
2009年12月 CHINESE JOURNAL OF ENGINEERING MATHEMATICS Dec. 2009

文章编号:1005-3085(2009)06-0962-07

一种新的神经网络预失真器及其算法*

崔 华

(长安大学信息工程学院，西安 710064)

摘 要: 针对高功率放大器 (High Power Amplifier, HPA) 的神经网络 (Neural Network, NN) 预失真器非直接学习方法中存在的预失真性能缺陷和直接学习方法中存在的计算复杂的弊端，本文基于非直接方法得到了HPA后逆滤波器的精确辨识，利用非线性算子的运算性质及一种近似方法分别推导出了新的NN预失真器学习结构及其相应的自适应算法。该算法由HPA的后逆滤波器辅助，直接产生HPA的前逆滤波器的输出。与直接学习方法相比，它大大简化了计算复杂度。仿真结果表明，本文提出的NN预失真器学习方法可以有效地改善非直接学习方法的预失真效果，进一步降低邻信道功率比约5dB。

关键词: 神经网络；预失真；直接学习方法；非直接学习方法

分类号: **AMS**(2000) 94A99 **中图分类号**: TN919 **文献标识码**: A

1 引言

高功率放大器 (High Power Amplifier, HPA) 工作在非线性区时，会使无线通信系统的传输信号 (如OFDM信号) 产生非线性失真，造成误比特率增加和邻信道干扰。自适应神经网络 (Neural Network, NN) 数字预失真是克服HPA非线性失真最有前途的一项技术[1]。NN预失真器大多是基于图1所示的非直接学习结构[2] 确定的，该方法先确定HPA的逆模型，然后将其系数复制到预失真器中实现HPA的线性化。但是，非直接学习方法的如下两个主要缺点严重影响了其性能[3]，第一个是HPA的反馈信号的测量噪声可能导致预失真器收敛到一个偏置值，第二个是将HPA的后失真器直接放在HPA前面充当其预失真器不能保证HPA线性化效果。

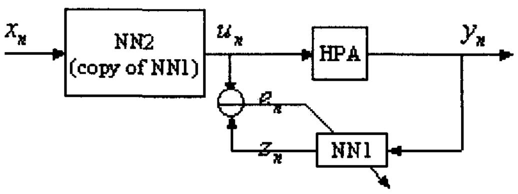

图1: NN预失真器的非直接学习结构

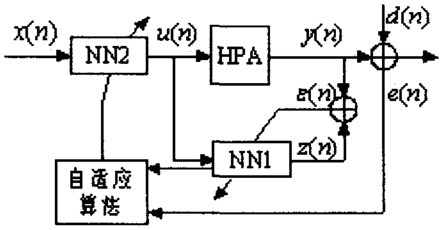

图2: NN预失真器的直接学习结构

收稿日期: 2007-10-30. **作者简介**: 崔华 (1977年1月生)，女，博士，讲师. 研究方向：小波分析理论与神经网络建模、算法及应用，功率放大器的线性化技术.

***基金项目**: 国家863项目 (2006AA01A116)；国家创新基金项目 (06026225101735).

Morgan等人针对第一个缺陷提出了改进方法，而NN预失真器的直接学习结构[4,5]可以对所述的两个缺陷都有所改善，但文献[4,5]中的直接学习方法不仅结构复杂而且计算量非常庞大。本文基于非直接方法得到的HPA的NN后逆滤波器的精确辨识和非线性算子的运算性质及一种近似方法提出了一种新的自适应NN预失真器学习方法，可以有效改善非直接学习方法的预失真效果，简化直接学习方法的计算复杂度。

2　NN预失真器的直接学习结构及其算法

图2是文献[4]中所述的预失真器的直接学习结构，其中NN1用来建模HPA的非线性特性，NN2是HPA的自适应的预失真器。我们期望的是当$x(n)$输入预失真器时，HPA的输出$y(n)$能充分接近$d(n)$，而$d(n)$是$x(n)$的线性放大，即

$$Y_n = G(F_2(X_n)) \approx KX_n, \tag{1}$$

这里K为HPA的期望线性放大倍数(不失一般性，这里取K为1)，F_2和G分别是NN2和HPA的传递函数。

NN预失真器的直接学习结构包括NN1和NN2的两个自适应算法。对于中等规模的NN，Levenberg-Marquardt误差反向传播(BP)算法是最好的选择[6]，权值W根据

$$\begin{cases} W(n+1) = W(n) - \eta\nabla W(n), \\ \nabla W(n) = -\frac{jW^T * \mathrm{Error}(n)}{jW^T * jW + I * \mu} \end{cases} \tag{2}$$

进行修正(这里省略了NN内部的BP算法)，其中η为训练步长，∇W为权值向量的调整量，Error为NN所有输出误差的和，网络的性能函数为均方误差(MSE)，用per表示，jW为per关于权值W的Jacobian信息，jW^T为jW的转置矩阵，I为单位矩阵，μ是自适应调整量，如果网络的MSE增大它就增大，如果网络的MSE变小它就变小，当μ增大到设定的最大值时网络的训练将停止。

显然，NN1的自适应学习算法可直接由式(2)所示的算法实现，其中

$$jW = \frac{\partial per(n)}{\partial W(n)} = -\mathrm{Error}(n)\frac{\partial z(n)}{\partial W(n)}, \tag{3}$$

而NN2的自适应学习算法为

$$\begin{cases} jW = \frac{\partial per(n)}{\partial W(n)} = -\mathrm{Error}(n)\frac{\partial y(n)}{\partial W(n)}\frac{\partial y(n)}{\partial W(n)} \\ \quad = \sum\limits_{r=0}^{M-1} \frac{\partial y(n)}{\partial u(n-r)} \cdot \frac{\partial u(n-r)}{\partial W(n)}, \end{cases} \tag{4}$$

其中M是HPA的记忆深度。假定步长μ足够小，使得权系数变换很慢，则有

$$W(n) \approx W(n-r), \tag{5}$$

故

$$\frac{\partial U(n-r)}{\partial W(n)} \approx X(n-r). \tag{6}$$

由NN1的自适应过程可知$y(n) \approx z(n)$，故

$$\frac{\partial y(n)}{\partial u(n-r)} \approx \frac{\partial z(n)}{\partial u(n-r)}. \tag{7}$$

该直接学习结构的自适应算法中，式 (4) 比式 (3) 多出两项，即需要计算前逆滤波器 NN2 的输出 $\{u(n-r), r=1, \cdots, M-1\}$ 和 NN1 的输出 $z(n)$ 对其输入的导数

$$\Big\{\frac{\partial z(n)}{\partial u(n-r)}, r=1, \cdots, M-1\Big\},$$

式 (4) 的运算相当复杂。正如文献 [4] 的结论所言，直接学习方法预失真性能的改善是以大大增加记忆存储空间、计算复杂度和结构实现复杂度为代价的，往往会导致这种结构的训练较慢或产生其它不理想的特性。

3 新的 NN 预失真器学习结构及其算法

3.1 改进的学习结构及其原理

如图 3(a) 框图所示，NN1 和 NN2 分别是 HPA 的后逆滤波器 (后失真器) 和前逆滤波器 (预失真器)，其非线性传递函数分别为 F_1 和 F_2，HPA 的传递函数为 G。先离线训练 NN1 得到后逆滤波器 F_1，然后再来确定前逆滤波器 F_2。根据非线性算子的逆的性质，有

$$F_1(G(X_n)) = G(F_2(X_n)). \tag{8}$$

现在，在式 (8) 的两端同时左乘 F_1，根据非线性算子的运算性质可得

$$F_1\big(F_1(G(X_n))\big) = F_1\big(G(F_2(X_n))\big), \tag{9}$$

式 (9) 可以用如图 3(b) 的框图表示。又因为 NN1 是 HPA 的后逆模型，即 F_1 是 G 的左逆函数，在理想误差内有

$$F_1(G(\cdot)) = I(\cdot), \tag{10}$$

其中 I 是单位矢量，所以有

$$F_1\big(F_1(G(X_n))\big) = F_1\big(G(F_2(X_n))\big) = F_1(X_n). \tag{11}$$

于是，我们就可以用图 3(b) 框图的实线部分作为前滤波器 NN2 的自适应学习结构，从而确定出预失真器的传递函数 F_2。

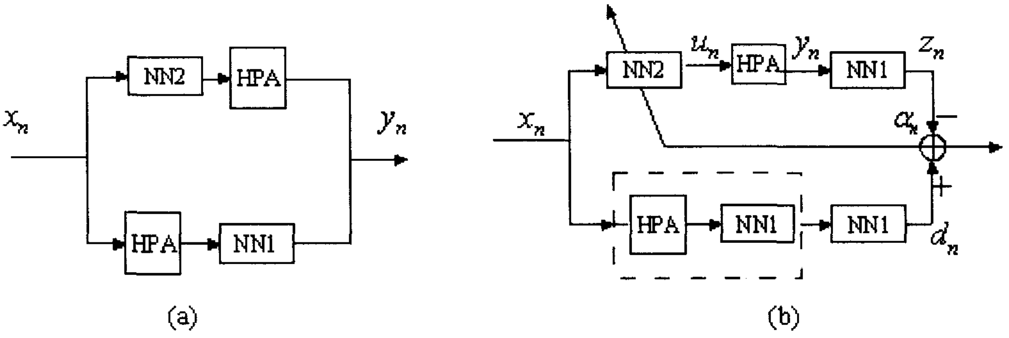

图 3: 改进的非直接学习结构的原理 (a) 及其实现方法 (b)

3.2 改进的NN预失真器直接学习结构的自适应算法

改进的NN预失真器的直接学习结构同第2节所述的直接学习结构一样，也包括两个子结构，即如图1所示的NN1和图3(b)框图所示的NN2的辨识结构，分别对应两个自适应算法。不同的是，在第一步自适应算法中，该方法辨识的NN1是HPA的后逆模型，而第2节的直接学习结构辨识的是HPA的正模型，但二者都是直接利用式(2)算法进行权值更新，故计算复杂度是一样的。

计算量的另一个来源是NN2的权值更新过程。从图3(b)可知NN2的自适应算法为

$$\begin{cases} jW = \frac{\partial per(n)}{\partial W(n)} = -\mathrm{Error}(n)\frac{\partial z(n)}{\partial W(n)}, \\ \frac{\partial z(n)}{\partial W(n)} = \sum\limits_{r=0}^{M-1} \frac{\partial z(n)}{\partial y(n-r)} \cdot \frac{\partial y(n-r)}{\partial u(n-r)} \cdot \frac{\partial u(n-r)}{\partial W(n)}. \end{cases} \tag{12}$$

式(12)比式(4)又多个求导项，其运算更加复杂。但是，由辨识HPA的后失真器NN1的自适应算法可知，当NN1收敛时，即如图1所示的$e_n \to 0$时，有$u_n \approx z_n$，故有

$$\frac{\partial z(n)}{\partial W(n)} \approx \frac{\partial u(n)}{\partial W(n)}. \tag{13}$$

用$\frac{\partial u(n)}{\partial W(n)}$近似代替$\frac{\partial z(n)}{\partial W(n)}$大大简化了计算，而且这种替代是可行的。因为$\frac{\partial z(n)}{\partial W(n)}$的正负影响着权值收敛的方向，$\frac{\partial z(n)}{\partial W(n)}$的绝对值的大小影响权值收敛变化的速度，对于神经网络权值的收敛，收敛方向是最重要的，收敛速度还可以通过其它因子调节。而$\frac{\partial u(n)}{\partial W(n)}$和$\frac{\partial z(n)}{\partial W(n)}$的方向是一致的，二者绝对值大小的误差可以通过调节式(2)所示算法中的η和μ来补偿。所以NN2的辨识就可以基于图3(b)框图的实线部分所示的训练结构，以NN1的权值为其初始权值，利用式(13)的近似代替，直接采用式(2)的算法，借助与NN1提供的参考模型，最终使得$y_n \to x_n$。由式(13)和(4)比较可知，该预失真器的权值更新算法避免了计算繁琐复杂的求导项

$$\left\{\frac{\partial z(n)}{\partial u(n-r)}, r = 1, \cdots, M-1\right\}$$

和预失真器的输出项$\{u(n-r), r = 1, \cdots, M-1\}$，大大降低了计算量和记忆存储空间。另外，NN2是时变的，我们无法利用信号间的延迟关系，即第2节所述的算法中，式(5),(6)很难保证，而该方法则不存在这个问题，并且当HPA的非线性阶数和记忆深度增加时，式(13)会比式(4)节约更多的计算量，该方法将显示出更大的优势。

4 仿真结果

为了验证本文所提出的NN预失真器学习方法的有效性和优越性，对OFDM系统中的HPA进行了自适应预失真仿真试验，并与文献[5]中研究的NN预失真器直接学习方法和文[7]中研究的NN预失真器非直接学习方法的预失真效果进行了比较。其中，仿真所用的HPA和OFDM信号的参数和文献[5]一致，并选取IBO[8]为2.93的OFDM信号；NN1和NN2都是3层BPNN，隐层神经元个数都为7个，输出层和隐层都采用Sigmoid传递函数，NN2训练中的学习速率取0.6。需要指出的是本文只研究幅度预失真，而相位预失真仍然采用文献[5]中的方法。

图4是预失真后的HPA的幅度响应，可见基于本文方法和文献[5]方法得到的幅度预失真效果确实比文献[7]方法的幅度预失真效果要好，特别是对接近饱和点的大信号而言。而本

文方法比文献 [5] 方法得到的幅度响应更理想，使得PD和HPA联合幅度响应几乎为一条斜率为1的直线，而文献 [5] 方法的幅度响应在中间部分有个别点发生振荡。

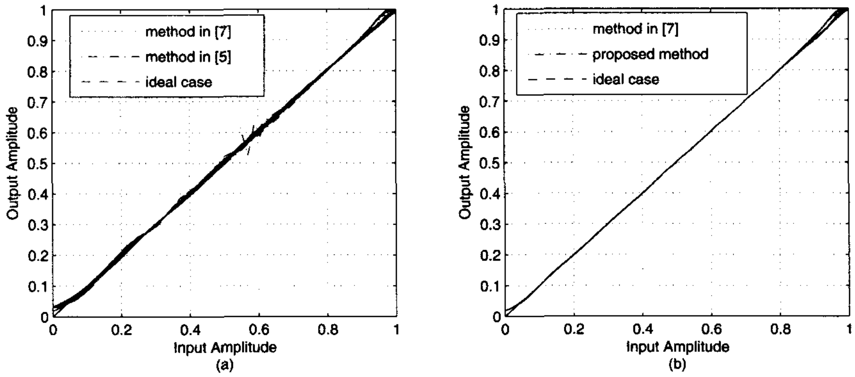

图 4: 预失真后的 HPA 的幅度特性 ((a) 文献 [5] 与文献 [7] 方法比较; (b) 本文方法与文献 [7] 方法比较)

图 5(a)、5(b)、5(c) 和 5(d) 分别为 HPA 输出信号星座图以及文献 [7] 方法、文献 [5] 方法和本文方法预失真后的 HPA 输出信号星座图，可见文献 [5] 方法和本文方法比文献 [7] 方法将星座图矫正得更好，进一步降低了误码率，而本文方法较文献 [5] 方法稍好。

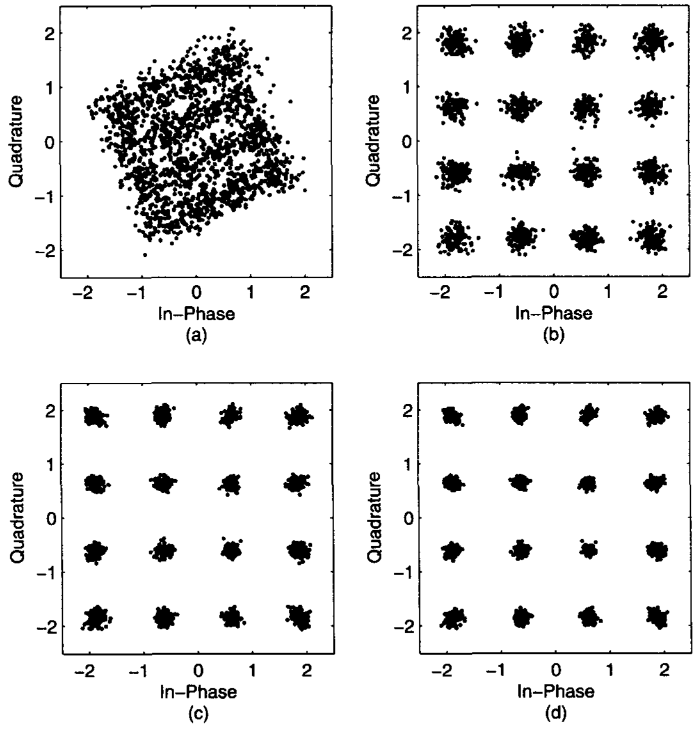

图 5: HPA 的输出信号星座图 ((a) 无预失真时; (b) 文献 [7] 方法预失真后; (c) 文献 [5] 方法预失真后; (d) 本文方法预失真后)

图6是由文献[5]方法、文献[7]方法和本文方法得到的预失真前后的HPA输出信号功率谱。文献[7]预失真方法能使邻信道功率比降低约10dB，文献[5]方法和本文方法能将其进一步降低约5dB，而本文方法的预失真效果略好与文献[5]方法。可见，本文所提出的NN预失真器直接学习方法不仅大大改善了文献[7]中研究的NN预失真器的非直接学习方法的预失真效果，而且在大大简化运算和结构实现复杂度的情况下仍具有稍好与文献[5]研究的直接学习方法的预失真效果。

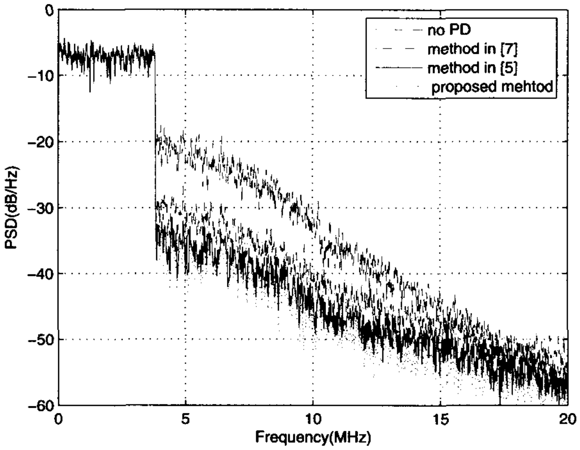

图6:　预失真前后HPA输出信号功率谱

5　结论

本文提出了一种新的NN 预失真器学习方法，仿真结果表明利用该方法得到的预失真效果比非直接学习方法的预失真效果要好，可进一步降低邻信道功率比约5dB，比文献[5]中的直接学习方法的预失真效果稍好些，而且可以大大减小计算复杂度和所需的存储空间，大大降低结构实现的难度，提高预失真器的收敛速度，避免训练中出现振荡等不理想特性。随着HPA 的非线性阶数和记忆深度的增加，该方法将显示出更大的优势。

参考文献：

[1] Ibnkahla M. Neural network predistortion techniques for digital satellite communications[C]// Proc IEEE ICASSP'00, 2004, 4: 3506-3509

[2] Eun C, Powers E J. A new Volterra predistorter based on the indirect learning architechtrue[J]. IEEE Trans Signal Processing, 1997, 45(1): 223-227

[3] Mathews V J, Sicuranza G L. Polynomial Signal Processing (Wiley Series in Telecommunications and Signal Processing)[M]. New York: Wiley-Interscience, 2000

[4] Lim Y H, *et al*. Adaptive nonlinear prefilter for compensation of distortion in nonlinear systems[J]. IEEE Trans Sig Process, 1998, 46: 1726-1730

[5] 崔华，宋国乡. OFDM系统的神经网络功放预失真[J]. 西安电子科技大学学报，2008, 35(2): 305-308

[6] 苏高利，邓芳萍. 论基于MATLAB语言的BP神经网络的改进算法[J]. 科技通报，2002, 19(2): 130-135

[7] Qian Y Q, Liu F Q. Neural network predistortion technique for nonlinear power amplifiers with memory[C]// Proc IEEE on Communications and Networking, 2006: 1-5

[8] Byung Moo Lee. Nonlinear and decidion-oriented signal processing for OFDM-based wireless communications[C]// IEEE APCCA, 2006: 980-983

A Novel Neural Network Predistorter and its Algorithm

CUI Hua

(School of Information Engineering, Chang'an University, Xi'an 710064)

Abstract: To circumvent the predistortion limitation of high power amplifiers (HPAs) in the indirect neural network (NN) predistorter learning methods and the computational complexity of direct methods, a novel learning structure and its corresponding algorithm are derived by the nonlinear inverse operator property and an approximation formula, respectively. This method is based on the precise identification of the HPA post-filter, and directly generates HPA pre-filter output, which greatly reduces the computational complexity of current direct learning methods. Simulations show the proposed method outperforms the indirect learning method in the term of about 5dB adjacent channel power ratio improvement.

Keywords: neural network; predistortion; direct learning method; indirect learning method